Requested Patent:

JP2001209565A

Title:

ASYNCHRONOUS REMOTE COPY:

Abstracted Patent:

EP1120711;

Publication Date:

2001-08-01;

Inventor(s):

NAKANO TOSHIO (JP); TABUCHI HIDEO (JP); NOZAWA MASAFUMI (JP); SHIMADA AKINOBU (JP) ;

Applicant(s):

HITACHI LTD (JP);

Application Number:

EP20000105491 20000315;

Priority Number(s):

JP20000024687 20000128 :

IPC Classification:

G06F11/14:

Equivalents:

ABSTRACT:

To provide a disk subsystem that assures the sequence and the coherence of data update regarding two or more disk subsystems, and to provide an asynchronous type remote copy function, a main center (9) that is a computer system having the configuration of slave subsystems (3-2 to 3-n) connected with a master disk subsystem (3-1) secures the coherence between data of the main center (9) and the remote center (10) at the temporary suspension by repeating temporary suspension and release of the temporary suspension of the remote copy by a master subsystem (3-1) at predetermined opportunities, and by repeating temporary suspension and release of the temporary suspension of the remote copy by slave subsystems (3-2 to 3-n) interlocking with it.

(19)日本国特許庁(JP)

(12) 公開特許公報(A)

(II)特許出願公開番号 特開2001-209565 (P2001-209565A)

(43)公開日 平成13年8月3日(2001.8.3)

(51) Int.Cl.7		識別記号	FΙ	ŕ~7 J ~}*((参考)
G06F	12/00	5 3 3	G 0 6 F 12/00	533J 5B0	6.5
		5 3 1		531D 5B0	8 2
	3/06	304	3/06	304F	

審査請求 未請求 請求項の数17 OL (全 11 頁)

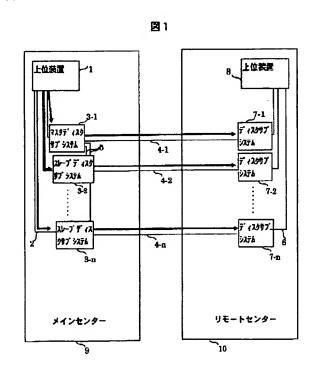
		各互明水	木明水 明水泵V数II OL (主 II 以)
(21)出顧番号	特膜2000-24687(P2000-24687)	(71)出願人	000005108
		·	株式会社日立製作所
(22)出顧日	平成12年1月28日(2000.1.28)		東京都千代田区神田駿河台四丁目 6番地
		(72)発明者	田渕 英夫
			神奈川県小田原市国府津2880番地 株式会
			社日立製作所ストレージシステム事業部内
		(72)発明者	島田 朗伸
			神奈川県小田原市国府津2880番地 株式会
			社日立製作所ストレージシステム事業部内
		(74)代理人	100075096
			弁理士 作田 康夫
			最終頁に続く

(54) 【発明の名称】 サプシステム及びこれらの統合システム

(57)【要約】

【課題】複数のディスクサブシステムにわたってデータ 更新の順序性、整合性を保証できる、非同期型のリモー トコピー機能を有するディスクサブシステムを提供す る。

【解決手段】メインセンター9では、一台のマスタサブシステム3-1にスレーブサブシステム3-2~3-nが接続されているコンピュータシステム構成であって、予め設定された契機でマスタサブシステム3-1がリモートコピーの一時停止停止と一時停止解除を繰り返し、これに連動してスレーブサブシステム3-2~3-nがリモートコピーの一時停止停止と一時停止解除を繰り返すことで一次停止じにおけるメインセンター9とリモートセンター10のデータの整合性を取る。



【特許請求の範囲】

【請求項1】上位装置とデータの授受を行う制御手段と、前記データの格納を行う記憶手段と、前記データを離れた場所に在るディスクサブシステムに予め定めた間隔でデータ転送/転送中断を行う手段とを有するマスタディスクサブシステムと、

それぞれが、前記上位装置とデータの授受を行う制御手段と、前記データの格納を行う記憶手段と、前記マスタディスクサブシステムに接続される伝送手段と、この伝送手段を使用して前記マスタディスクサブシステムがデータ転送状態か転送中断状態かを問い合わせる問い合わせ手段と、この問い合わせの結果マスタディスクサブシステムがデータ転送状態である時に前記データを離れた場所に在るディスクサブシステムに転送する手段とを有する複数のスレーブディスクサブシステムと、

前記マスタ及びスレーブディスクサブシステムとは離れた場所に在り、前記各サブシステムから転送されるデータを受け取る制御手段と、このデータの格納を行う記憶手段とを有する複数のリモートディスクサブシステムとを有し、

前記マスタ及びスレーブディスクサブシステムは前記リモートサブシステムにデータを間欠的に転送する事で、 転送中断時における前記マスタ及びスレーブサブシステム内のデータと前記リモートディスクサブシステム内の データとの一貫性を確保する統合システム。

【請求項2】スレーブサブシステムのリモートコピー方法であって、

上位装置からデータを受取り、このデータを記憶手段に格納し、マスタサブシステムがデータをリモートセンタに転送する状態かをマスタサブシステムに問い合わせ、前記マスタサブシステムが転送する状態の場合には前記データをリモートセンターに転送し、前記マスタサブシステムが転送しない状態の場合には前記データの格納位置に関する情報を保持し、前記マスタサブシステムが転送する状態となってからリモートセンターに転送するリモートコピー方法。

【請求項3】上位装置に対し情報の授受を行う制御部と、前記情報の格納を行う記憶部と、前記上位装置からの前記情報を他のサブシステムに設定した契機で一時停止しつつ転送する転送手段を備えるサブシステム。

【請求項4】前記サブシステムは、前記一時停止とこの一時停止の解除を周期的に行う請求項3に記載のサブシステム。

【請求項5】前記一時停止時には、転送すべき更新情報 の格納位置情報を自サブシステム内に一時停止解除まで 保持する請求項3に記載のサブシステム。

【請求項6】上位装置と情報の授受を行う制御部と、前記情報の格納を行う記憶部と、前記上位装置からの前記情報を他の場所に在るサブシステムに転送する転送部とを備える第一のサブシステムと、

上位装置と情報の授受を行う制御部と、前記情報の格納を行う記憶部と、前記上位装置からの前記情報を他の場所に在るサブシステムに転送する転送部と、前記マスタサブシステムと接続する伝送経路とを備える複数のサブシステムとからなる統合システム。

【請求項7】前記複数のサブシステムは、前記伝送経路を用いて前記第一のサブシステムの転送状態を入手する 請求項6に記載の統合システム。

【請求項8】上位装置とデータの授受を行う制御部と前記データの格納を行う記憶部とをそれぞれに有し、前記上位装置からの前記データを他の場所に在るディスクサブシステムに転送するディスクサブシステムを複数備えた統合システムであって、

前記上位装置に接続される複数のディスクサブシステム のうち第一のディスクサブシステムに対して、他のディ スクサブシステムが前記他の場所に在るディスクサブシ ステムへの前記データの転送可否を問い合わせる統合シ ステム

【請求項9】前記転送の可否は、前記第一のディスクサブシステムが転送を一時停止しているか否かで判断する 請求項8に記載の統合システム。

【請求項10】前記第一のディスクサブシステムは、前記一時停止とこの一時停止の解除を周期的に行う請求項9に記載の統合システム。

【請求項11】前記上位装置に接続された前記ディスクサブシステムと前記他の場所に在るディスクサブシステムとのデータ転送は、非同期型で行う請求項8に記載の統合システム。

【請求項12】上位装置に接続された第1のディスクサブシステム群と、この第1のディスクサブシステム群からデータの転送を受ける第2のディスクサブシステム群を有する統合システムであって、

前記第1のディスクサブシステム群のディスクサブシステムの中で1つは、前記第1のディスクサブシステム群が前記第2のディスクサブシステム群へデータ転送する際における、転送の可否を管理するマスタサブシステムである統合システム。

【請求項13】前記転送の可否は、前記マスタサブシステムが前記第2のディスクサブシステム群へのデータ転送を一時停止しているか否かで判断する請求項12に記載の統合システム。

【請求項14】前記第1のディスクサブシステム群と前記第2のディスクサブシステム群との間は、SAN (Storage Area Network)を介して接続されている請求項12に記載の統合システム。

【請求項15】前記第1のディスクサブシステム群と前記第2のディスクサブシステム群との間のデータ転送は、非同期型で行う請求項12に記載の統合システム。

【請求項16】前記非同期型のデータ転送に際し、更新 順序保証の要否を専用のディスクボリュームを指定する ことによって明示する請求項15に記載の統合システム。

【請求項17】上位装置からデータを受取り、このデータを記憶手段に格納し、マスタサブシステムがデータをリモートセンタに転送する状態か否かをマスタサブシステムとの一貫性を確保する一貫性保全方法。

【発明の詳細な説明】

[0001]

【発明の属する技術分野】本発明はコンピュータシステムのデータを格納する外部記憶装置及びこれらの統合システムに関し、特に、遠隔地に存在する複数の外部記憶装置群とを相互に接続し、上位装置たるホストコンピュータを経由せずに、遠隔地に存在する外部記憶装置(サブシステム)との間で、データを二重化するリモートコピー技術に関する。ここで、サブシステムとは、上位装置に対し情報の授受を行う制御部と、情報の格納を行うディスク装置等を内蔵する記憶装置をいうものであり(記憶装置がディスク装置の場合はディスクサブシステムから構成されるシステムをいうものとする。

[0002]

【従来の技術】地震等の天災の際のデータのバックアップを考慮すれば、メインセンターとリモートセンターは100km〜数100km程度、分離する必要がある。このため、メインセンターとリモートセンターにそれぞれ設置されているサブシステムの間で、データを二重化して保有する、いわゆる、リモートコピー機能を採用した外部記憶システムが、既にいくつか実用化されている。

【0003】リモートコピー機能は、同期型と非同期型の2種類に大別される。

【0004】同期型とはメインセンター内のホストコンピュータ(上位装置)からサブシステムに、データの更新(書き込み)指示が有った場合、その指示対象がリモートコピー機能の対象でもあるときは、そのリモートコピー機能の対象であるリモートセンターにおけるサブシステムに対して、指示された更新(書き込み)が終了してから、メインセンターの上位装置に更新処理の完了を報告する処理手順をいう。この場合、メインセンターとリモートセンターとの地理的距離に応じて、この間に介在するデータ伝送線路の能力の影響を受け、時間遅れ(伝送時間等)が発生する。

【0005】これに対し非同期型とは、メインセンター内の上位装置からサブシステムに、データの更新(書き込み)指示が有った場合、その指示対象がリモートコピー機能の対象であっても、メインセンター内のサブシステムの更新処理が終わり次第、上位装置に対し更新処理の完了を報告し、リモートセンターのサブシステムにお

けるデータの更新(反映)はメインセンターにおける処 / 理とは非同期に実行する処理手順をいう。このためメインセンター内部で必要とされる処理時間でデータ更新が終了するので、リモートセンターへのデータの格納に起因する伝送時間等はかからない。

【0006】非同期型は、リモートセンターのサブシステムの内容が、メインセンター側のそれに対し、常に一致しているわけではない。このため、メインセンターが災害等により機能を失った場合は、リモートセンター側にデータの反映が完了していないデータが消失することとなる。しかし、メインセンター側のサブシステムのアクセス性能を、リモートコピー機能を実施しない場合と同等レベルとすることができる。

【0007】かかる従来技術では、次の様な課題があっ た

【0008】「一貫性保全について」リモートコピーを行う場合、メインセンターのサブシステムとリモートセンターのサブシステム間は独立した通信リンクで接続される。つまり、メインセンターの複数のサブシステムの間でリモートコピーを行う場合は、独立した通信リンクで接続されたサブシステムの組が複数存在する構成となる。

【0009】この構成では、リモートセンターへのコピーは各通信リンク毎に行われるため、サブシステムによりデータの更新された時刻が異なる。そのため、メインセンターが機能を失った場合に、どの時点までのデータがリモートセンターにコピーされていたのかが各サブシステム毎に異なるため、データ毎にタイムスタンプ等が付けられていない場合、メインセンターとリモートセンターの整合性を取ることが出来なかった。

【0010】このように、複数のサブシステムを有するメインセンターのバックアップをリモートセンターで行う場合、複数のサブシステム間でデータの一貫性を保全する(更新順序を保持する)という課題がある。尚、ここにおける「順序」とは、単なるデータの順番ではなく、リモート側の各サブシステムにおけるデータ更新の一貫性がある「状態」という意味で使用している。

【0011】非同期型リモートコピーでは、リモートセンターへの更新データの反映が、メインセンターでの実際の更新処理の発生時点より遅れて処理されることはやむを得ない。しかし更新の順序はメインセンターと一致していなければならない。もしくは間欠的に見てメインセンターで発生した更新処理の順序とリモートセンターの更新処理の順序は整合性の取れた状態になければならない。

【0012】一般にデータベース等はデータベース本体 と各種ログ情報、制御情報から構成されており、それぞ れが関連性を持っている。データ更新の際はデータベー ス本体に加え、これらログ情報、制御情報をも更新し、 システムの整合性が保たれている。したがって更新の順 序が崩れた場合、更新順序に関連するこれらの情報の整合性も崩れ、最悪の場合には、データベース全体の破壊につながる可能性がある。

【0013】「上位装置が介在することについて」メインセンター及びリモートセンターに複数のサブシステムが存在する一般的な環境で非同期型のリモートコピーを実現する場合には、上位装置がサブシステムへデータの更新を指示する場合、タイムスタンプなどの更新順序に関する情報をデータに付加し、これらの情報に基づいて副側のサブシステムの更新データ反映処理が実行されるのが一般的である。例えば、特開平6-290125号公報(米国特許第5446871号)に示されるリモートコピーの様に、上位装置が介在してリモートコピー機能を実現している。

【0014】特開平6-290125号公報(米国特許第5446871号)に開示されている技術においては、メインセンター側の上位装置のオペレーティングシステムとディスクサブシステム、リモートセンター側の上位装置のデータムーバーソフトウェアとディスクサブシステムの連携により、更新順序情報の発行、送付、これに基づく更新データ反映処理を実現している。

[0015]

【発明が解決しようとする課題】従来技術により、メインセンター、リモートセンター間の更新順序性を保証しながら非同期型のリモートコピー機能が実現できる。しかし従来技術では、上位ソフトウェアとサブシステムの双方にこの機能実現の為の仕組みが必要であり、且つ、両者が連携しなければならない。そのため専用の新規ソフトウェアの導入が必要となり、ユーザは、ソフトウェアの導入、設定、検査、CPU負荷増加に伴うシステム設計の見直し等の作業が発生する。このためこの機能を導入するためにはかなりの期間を要し、費用が発生してしまう。

【0016】また、サブシステムの機能のみで非同期型のリモートコピー機能を実現する場合は、サブシステムの機能のみでデータの更新順序の整合性を保持する必要が有る。更新順序の整合性が必要なデータが複数のサブシステムに分散されて格納されている場合、複数のサブシステム間で更新順序の整合性を保持するための手段が無いという課題もあった。また、更新順序を保持することによるサブシステム内部の処理オーバヘッドの増加を防ぐことも課題の一つである。

【0017】本発明の目的は、上位装置に対して新規ソフトウェアの導入を必要とせず、サブシステムの機能で、データの整合性を保証でき、導入が容易かつメインセンターの性能低下が少ない、非同期型のリモートコピー機能を実現することである。

[0018]

【課題を解決するための手段】相互に遠隔地に存在する メインセンターとリモートセンターのサブシステム同士 を接続する。サブシステムが複数の場合は、メインセンターにおいて、サブシステムのうちの一台に(以下、マスタサブシステムと呼ぶ)、他のサブシステム(以下、スレーブサブシステムと呼ぶ)をすべて接続する。

【0019】メインセンターのマスタサブシステムは、リモートコピーの一時停止や一時停止の解除を行う。これらの動作契機はユーザがマスタサブシステムに予め設定しておく事により、リモートコピー実施中の任意の時点で実施する。メインセンターのサブシステムは上位装置より更新データを受け取ると、自サブシステムへのデータの格納を開始する。

【0020】そして、マスタサブシステムは自サブシステムがリモートコピーを一時停止した状態になっているか否かを確認し、一時停止状態になっていない場合は、当該データをリモートセンターへの送付対象とする。また、スレーブサブシステムは、ホストからの更新データを受け取った際にマスタサブシステムの状態を後述する制御ビットにて確認し、マスタサブシステムがリモートコピーを一時停止させる状態になっていないことを確認した場合のみ更新データをリモートセンターへの送付対象とする。

【0021】スレーブサブシステムがマスタサブシステムの状態を確認した際に、マスタサブシステムがリモートコピーを一時停止する状態になっていると、スレーブサブシステムはマスタサブシステムと同様にリモートコピーを一時停止する状態となる。一時停止状態では、マスタサブシステム、スレーブサブシステムを問わず、リモートセンターへのデータ送付は行わず、メインセンター側でのみ更新処理を行い、更新情報を各サブシステム内で管理・保存する。マスタサブシステムにおいて、リモートコピーの一時停止状態が解除された後は、マスタサブシステム、スレーブサブシステムともリモートセンターへのデータ送付を再開する。この場合、一時停止状態の間にメインセンタで更新されたデータも送付データの対象となる。

【0022】このようにして、メインセンターとリモートセンターの各サブシステムの各ボリュームの間は、非同期型のリモートコピーによりデータの二重化を行う。 【0023】

【発明の実施の形態】以下、図面を参照しながら本発明 をコンピュータシステムに適用した場合の一例について 説明する。

【0024】図1に、コンピュータシステムを装備した 複数のデータセンターにおいて、任意の2つのセンター 間で情報(データ)の二重化を行うために、本発明を適 用したときの構成例を示す。

【0025】メインセンター9側の一台又は複数台のディスクサブシステム3と、リモートセンター10側の一台又は複数台のディスクサブシステム7は、上位装置(ホストコンピュータ)1、8を介さずに接続され、両

センター間でデータの二重化を行うリモートコピーシステムを実現している。上位装置を介さないディスクサブシステムの接続としては、例えばSAN(Storage Area Network)が挙げられる。図4にメインセンター9のディスクサブシステム3の構成例を示す。

【0026】図1のメインセンター9において、データ 処理を行う中央処理装置 (CPU)を持つ上位装置1 は、伝送経路であるインタフェースケーブル2を介して、ディスクサブシステム3-1 (マスタサブシステム)、3-2、……3-n (スレーブサブシステム) に接続されている。

【0027】ディスクサブシステム3-1、3-2、……3-nは、上位装置1からのデータ(情報を含む) 授受を行うインタフェース制御部11と、上位装置1から参照又は更新されるデータデータを格納するバッファ12と、リモートコピーが一次停止中の更新データの格納位置に関する情報を格納するリモートコピー制御情報格納部16と、このデータを記録する記録媒体としての磁気ディスクドライブ13、これらのデータのやり取りを制御するマイクロプロセッサ14、これらの各要素を制御するディスクアレイサブシステム制御部17を備える。

【0028】また、マスタディスクサブシステム3-1 はそれに加えてリモートコピーをどのような設定にて行うかをユーザが設定するサービスプロセッサパネル15を備える。そしてリモートコピー制御情報格納部16は、リモートコピーが一次停止中の更新データの格納位置に関する情報に加えサービスプロセッサパネル14により設定された制御情報より現在のリモートコピー状況を表す制御ビットを格納する。

【0029】マスタディスクサブシステム3-1はインタフェースケーブル4-1を介してリモートセンタ10のディスクサブシステム7-1と接続される。同様に、スレーブディスクサブシステム3-2はインタフェースケーブル4-2を介してリモートセンタのディスクサブシステム7-2と接続され、スレーブディスクサブシステム3-nはインタフェースケーブル4-nを介してリモートセンタのディスクサブシステム7-nと接続される構成をとる。

【0030】なお、インタフェースケーブル4-1、4-2、……4-nは、回線接続装置等を利用して一般の通信回線と接続することも可能である。本例ではこの点も含めてインタフェースケーブル4-1~nとして記述する。

【0031】また、ディスクサブシステム3が複数台有る場合には、ディスクサブシステム3-1はメインセンター9内でリモートコピー対象のデータが格納されるディスクサブシステム3-1以外のディスクサブシステム3-2、……3-nとインタフェースケーブル5を介して接続されている。この様に、メインセンター9側で

はリモートコピー対象のデータが格納されるディスクサブシステム3について、1台のマスタディスクサブシステム3-1とその他のスレーブディスクサブシステム3-2、……3-nがインタフェースケーブル5で接続される構成をとる。

【0032】マスタディスクサブシステム3-1は、上位装置1がマスタディスクサブシステム3-1にデータの書き込み要求を発行すると、これに同期して当該データを自己のサブシステム内のデータバッファ12に書き込み、更に自己のサブシステム内のデータバッファ12にデータが書き込まれたこととは非同期に、遠隔地に存在するディスクサブシステム7-1に対し、データの書き込み指示を行うディスクサブシステムである。自己のサブシステム内のデータバッファ12に書き込まれた当該データは、同期或いは非同期にて磁気ディスクドライブ13に記録される。

【0033】非同期型の遠隔地にデータを書き込むリモートコピー方法として、メインセンター9のディスクサブシステム3は、自己のサブシステム内のボリュームが更新された順番に従い、自サブシステムが接続されているリモートセンター10のディスクサブシステム7に更新データを送付し、リモートセンター10のディスクサブシステム7は受け取った順番に従い、更新データを自己のサブシステム内のボリュームに反映するモードと、メインセンター9側が自己のサブシステム内のボリュームが更新された順番によらずディスクサブシステム3で最適にスケジューリングされた契機で送付対象のデータをまとめて送信し、リモートセンター10のディスクサブシステム7は受け取った順番に関係なく更新データを自己のサブシステム内のボリュームに反映するモードを保有する。

【0034】スレーブディスクサブシステム3-2、… ……3-nは、上位装置1がディスクサブシステム3-2、……3-nにデータの書き込み要求を発行する と、これに同期して当該データを自己のサブシステム内 のデータバッファ12に書き込み、さらにマスタディス クサブシステム3-1のリモートコピー制御情報格納部 16の状態を参照し、リモートコピーの状態により、自 己のサブシステム内のデータバッファ12にデータが書 き込まれたこととは非同期に、遠隔地に存在するディス クサブシステム7-2、……7-nに対し、データの 書き込み指示を行うか、もしくは更新データの格納位置 に関する情報を自サブシステム内のリモートコピー制御 情報格納部16に保持するかを判断するディスクサブシ ステムである。ディスクサブシステム7-1、7-2、 ………7-nは、インタフェースケーブル4により接続 されたディスクサブシステム3-1、3-2、……3 - nから受け取ったデータを、自己のサブシステム内の データバッファ12に格納する。

【0035】つまり、上位装置1から一台または複数台

のディスクサブシステム3-1、3-2、……3-n に対しデータの書き込み指示があった場合には、ディス クサブシステム3-1の状態次第で、リモートセンター 10内の一台または複数台のディスクサブシステム7-1、7-2、……7-nにも同じデータが格納される システム構成を示している。図1の矢印は、上位装置1 から書き込み指示のあったデータの流れを示している。 【0036】なお、マスタディスクサブシステム3-1 は、リモートコピーの状態を表す制御ビットをリモート コピー制御情報格納部16内に持っているので、システ ム運用者により予め設定された契機もしくは任意の時点 でのシステム運用者による指示に基づき、この制御ビッ トの情報を変更することによってリモートコピーを一時 停止状態にすることができる。リモートコピーが一時停 止のときは、ディスクサブシステム3-1、3-2、… ……3-nは自己のディスクサブシステムのデータバッ ファ12へ更新データの格納を行うと共に、一時停止状 態となった時点以後に受領した書き込み指示についての 更新データの格納位置に関する情報をリモートコピー制 御情報格納部16に保持しておき、ディスクサブシステ ム7-1、7-2、……7-nへの更新データの書き 込み指示の発行は行わず保留する。

【0037】本願発明では、このようにリモートコピーを一時停止させることにより、リモートセンター10側の全てのサブシステムにおいて、リモートコピーが一時停止させた時点のメインセンター9側のデータが存在する事となる。つまり、一時停止した時刻における、メインセンター9側のデータとリモートセンター10側のデータとの整合性を取ることが出来る。よって整合性を取るためのタイムスタンプをデータに付加させる必要が無くなり、時間情報が上位装置から付加されてこないオープン系のシステムであっても、上位装置の介在無しでリモートコピーを実現することができる。

【0038】また、ディスクサブシステム3-1、3-2、……3-nは、予めシステム運用者によりマスタディスクサブシステム3-1に設定された契機もしくは任意の時点でのシステム運用者による指示に基づき、上記一時停止状態を解除することができる。

【0039】一時停止状態が解除されると、ディスクサブシステム3-1、3-2、……3-nは、一時停止している間に更新のあったデータの書き込み指示をディスクサブシステム7-1、7-2、……7-nに対して発行するとともに、上位装置1からディスクサブシステム3-1、3-2、……3-nへデータの書き込み要求が発行された場合は、これに同期して当該データを自己のサブシステム内のデータバッファ12に書き込み、更に、自己のサブシステム内のデータバッファ12にデータが書き込まれたこととは非同期に、遠隔地に存在するディスクサブシステム7-1、7-2、……7-nに対し、データの書き込み指示を行う。

【0040】このような構成とする事により、メインセンター9内のリモートコピー対象のディスクサブシステム3のボリュームと、リモートセンター10内のディスクサブシステム7のボリュームにおいて、更新処理タイミングの遅れ等を無視できれば、同一のデータが保持される。さらに、マスタサブシステム3-1においてリモートコピーが一時停止状態となっている間は、マスタサブシステム3-1が一時停止状態となった時点のメインセンタ9の各ディスクサブシステム3のデータの状態、つまり当該時点で一貫性が保証されたデータの状態が、リモートセンター10の各ディスクサブシステム7で保証・維持される。

【0041】なお、リモートコピーの一時停止や一時停止の解除は、リモートコピーのボリュームペア単位に設定できる。複数のボリュームペアを一つのボリュームグループに設定して、ボリュームグループ単位に状態を変化させることも可能である。そして、一時停止や一時停止解除を何れかのサブシステム3,7や上位装置1,8のコンソール、或いはこれらのシステムを管理する際に使用するモニターに表示することによって、ユーザはリモートコピーが現在行われているか否か、またどのような単位でリモートコピーが行われているかを認識する事ができる。

【0042】このリモートコピーの一時停止及び一時停止解除の間隔は、一時停止される前の全データがリモートセンター10側にコピーされる前に、一時停止が解除され新しいデータがリモートセンター10側にコピーされてしまい、メインセンター9側とリモートセンター10側とで整合性がとれなくなる程の短時間で無い限り、ユーザの任意に設定する事が可能である。

【0043】ここではリモートセンター10内においてリモートコピー一時停止状態の時点のサブシステム7のデータを保存するために行うコピーの時間を考えた一例として、30分間メインセンター9からリモートセンター10へのリモートコピーを行い、次の30分間は一時停止、その後に一時停止を解除して再び30分間リモートコピーを行うというサイクルを挙げておく。もちろんリモートセンター10内でのコピー時間が30分でない場合には、コピー時間に併せて一時停止をする時間を変えてよいし、コピー時間に囚われずに一時停止及び一時停止解除の間隔を設定してもよい。

【0044】また、マスタディスクサブシステム3-1 内のリモートコピー制御情報格納部16に格納されたリモートコピー状態を表す制御ビットを、マスタディスクサブシステムがスレーブディスクサブシステム3-2、……3-nにインタフェースケーブル5を用いて予め配信しておくことにより、スレーブディスクサブシステムに制御ビットを問い合わせる必要を無くする構成としてもよい。その場合には、スレーブディスクサブシステムのリモートコピー制 御情報格納部16にマスタディスクサブシステムのリモートコピー制御情報格納部16と同様にスレーブサブシステム自身の状態管理も格納する。

【0045】上位装置8は、リモートセンター10においてディスクサブシステム7-1、7-2、……7-nとインタフェースケーブル6によって接続され、ディスクサブシステム7-1、7-2、……7-nに対し、参照及び更新を行う中央処理装置である。上位装置8は、メインセンター9の上位装置1が災害や故障等により本来の機能を果たせなくなった場合に、上位装置1の代替となって処理を行うことが出来る。このほか、ディスクサブシステム7-1、7-2、……7-nに格納されているデータを使用して、メインセンター9の上位装置1とは異なる処理を、上位装置1とは別個独立に実行することができるものである。

【0046】但し、上位装置8がディスクサブシステム7-1、7-2、……7-nに対し処理を行わない場合、上位装置1の代替機能を備えない場合には、上位装置8は不要である。逆に、上位装置8を備え、ディスクサブシステム7-1を他のディスクサブシステム7-2~7-nとインタフェースケーブル5で接続し、メインセンター9のマスタディスクサブシステム3-1と同様の構成とすることで図1のメインセンター9をリモートセンターに、リモートセンター9をメインセンターとして機能させる事も可能である。

【0047】本発明の実施の形態として、データの二重 化方法と運用の概略を図2を用いて説明する。

【0048】二重化の対象となるデータが格納されたファイルやボリューム、ディスクサブシステム3は、事前に運用者が二重化つまりリモートコピーの必要に応じて選択する。そして、対象ファイルや対象ボリューム及びディスクサブシステム3と、選択したデータの複製を格納するファイルやボリューム及びディスクサブシステム7との関係や、二重化する際に更新順序の整合性を常時保持する必要が有るか否かを、予め運用者が上位装置1或いはサービスプロセッサ15等からマスタディスクサブシステム3-1内のリモートコピー制御情報格納部16に対し設定しておく。通常は、データベースの更新履歴であるログファイル等のみに限って更新順序の整合性を常時保持する設定とする場合が多いが、本例ではファイルの種別に関わらず更新順序を常時保持する設定はしないこととする。

【0049】また、マスタサブシステム3-1については、リモートコピーを一時停止させる契機、並びに一時停止を解除する契機を設定する。契機の設定は、上位装置1から指示できるため、運用の自動化を支援する上位装置1のプログラムにより上位装置1からの指示契機を予めスケジューリングしておくことが可能である。

【0050】上記の選択、設定に際し、専用のコンソールやサービスプロセッサ15を接続又は装備できるディ

スクサブシステム3の場合には、上位装置1を利用せず、そのコンソールやサービスプロセッサ15を通じて設定できる。本例では、上位装置1を利用せず、ディスクサブシステム3内部で保有する時間値を利用して、予め運用者がマスタサブシステム3-1において、定期的にリモートコピーの一時停止、並びに一時停止の解除が実施されるように設定しておく。

【0051】図2のフローは専用のコンソールから選択・設定を行う場合を示している。なお、リモートコピーの一時停止や一時停止解除の設定は、リモートコピー対象のボリュームペア単位に設定する(ステップ1:図ではS1の様に示す。以下同じ)。通常は、リモートコピー対象のボリュームペアすべてを一つのボリュームグループとして定義し、ボリュームグループ内のボリュームはすべて同一のステータスとなるように設定する。

【0052】本例では、ディスクサブシステム3のボリューム全てをリモートコピー対象とする。従って、以下では、リモートコピーの状態を、ボリュームペアやボリュームグループ単位ではなく、ディスクサブシステム単位として記述する。なお、本例では詳細は記述しないが、データベースとログファイルとはボリュームグループを分けて設定し、ログファイルを格納するボリュームについては、リモートコピーの一時停止契機や一時停止解除契機を設定しないといった定義も可能である。

【0053】リモートコピー対象のファイルやボリュームの設定方法としては、ボリュームやディスクサブシステムを意味する具体的なアドレスを指定する方法や、ディスクサブシステム内の制御プログラムによって、アドレスの任意の範囲から選択する方法を取ることもできる。初期設定として、パス設定やペア設定、並びに一時停止契機や一時停止解除契機の設定を行う例を示してある。

【0054】上位装置1から、ディスクサブシステム3 -1に対し、データの書き込み要求(以下、ライトコマ ンド)が発行される(ステップ2)と、ディスクサブシ ステム3-1はライトコマンドにもとづき自己のディス クサブシステム内へデータ格納処理を実行し(ステップ 3)、自己のサブシステム内へのデータ書き込み(格 納) 処理が完了した後に、上位装置1に対しライトコマ ンドに対する処理の完了報告を行う(ステップ4)。 【0055】また、上位装置1から、ディスクサブシス テム3-2、……、3-nに対し、ライトコマンドが 発行されると(ステップ2)、ディスクサブシステム3 -2、……、3-nはライトコマンドに基づき自己の ディスクサブシステム内へデータ格納処理を実行する (ステップ5)。ここで、ライトコマンドとは、データ を書き込むための指示と書き込みデータそのものとを転 送するコマンドであり、どのディスクサブシステムに要 求を出すのかはユーザが予め上位装置1に対して設定し ておく(ステップ1)。

【0056】ライトコマンドを受領した際、ディスクサ ブシステム3-1は、自サブシステムのリモートコピー の状態を表すリモートコピー制御情報格納部16内の制 御ビットを参照し、自サブシステムのリモートコピー状 態を判別する(ステップ6:図3)。自サブシステムが リモートコピー一時停止状態であった場合、ディスクサ ブシステム3-1は自サブシステムに接続されているリ モートセンター10のディスクサブシステム7-1へは 更新データの送信は行わず、更新が実施されたデータの 格納位置に関する情報を自サブシステム内に保持してお く(ステップ7)。自サブシステムがリモートコピーー 時停止状態になければ、自己のサブシステムの処理能力 に基づいて決定された契機で、ライトコマンドをディス クサブシステム7-1に対し発行する(ステップ8)。 【0057】なお、リモートコピー一時停止状態の間に 更新が行われたデータの格納位置情報を保持している場 合は、当該位置のデータもリモートセンタ10のディス クサブシステム7-1への送付対象と判断し、当該デー タを書き込む為のライトコマンドを発行し、ライトコマ ンドに対する処理が完了した後に更新位置情報を消去す る。

【0058】ライトコマンドを受領した際、ディスクサブシステム3-2、……3-nは、ディスクサブシステム3-1に対しインタフェースケーブル5を経由してディスクサブシステム3-1の状態を問い合わせるコマンドを発行し、ディスクサブシステム3-1のリモートコピー状態を表す制御ビットを取得・参照する(ステップ9)ことにより、ディスクサブシステム3-1がリモートコピー一時停止状態にあるか否かを確認する(ステップ10)。

【0059】ディスクサブシステム3-2、……3-nはディスクサブシステム3-1がリモートコピー一時停止状態であった場合、更新が実施されたデータの格納位置に関する情報を自サブシステム内に保持(ステップ12)しておき、上位装置1に対しライトコマンドに対する処理の完了を報告する(ステップ13)。

【0060】また、ディスクサブシステム3-1がリモートコピー一時停止状態でない場合は、ディスクサブシステム3-2、……、3-nは、上位装置1に対しライトコマンドに対する処理の完了を報告し(ステップ14)、自己のサブシステムの処理能力に基づいて決定された契機で、ライトコマンドをディスクサブシステム7-2、……7-nに対し発行する。なお、リモートコピーー時停止状態の間に更新が行われたデータの格納位置情報を保持している場合は、当該位置のデータもリモートセンタのディスクサブシステム7-2、……7-nへの送付対象と判断し、当該データを書き込む為のライトコマンドを発行し(ステップ15)、ライトコマンドに対する処理が完了した後に更新位置情報を消去する。

【0061】つまり、ディスクサブシステム3-1がリモートコピー一時停止状態に有れば、ディスクサブシステム3-1に接続されているメインセンタ9の他のディスクサブシステムは上位装置1からライトコマンドが発行される事に起因しすべてリモートコピー一時停止状態となる。また、ディスクサブシステム3-1がリモートコピー一時停止状態でなければ、ディスクサブシステム3-1に接続されているメインセンタ9の他のディスクサブシステムは上位装置1からライトコマンドが発行される事に起因しリモートコピーが実施される。

【0062】尚、ディスクサブシステム3-2、………3-nがディスクサブシステム3-1に問い合わせる (ステップ9) 代わりに、ディスクサブシステム3-1 が自らのリモートコピー状態が変化していた場合に、ディスクサブシステム3-2、……3-nがディスクサブシステム3-1にその変更を伝える (ステップ9': 図示せず)ような設定、或いは先にも述べたように、ディスクサブシステム3-1が自らのリモートコピー状態が変化した際にディスクサブシステム3-1がディスクサブシステム3-2、……3-nにその変更を伝える設定としてもよい。

【0063】この様な設定とした場合には、ディスクサブシステム3-2、……3-nにおいても、ディスクサブシステム3-1と同様に自らのリモートコピーの状態を保存しておく必要があるため、ステップ10においてディスクサブシステム3-1がリモートコピー一時停止状態であった場合、自ディスクサブシステムのリモートコピー状態を一時停止状態に変更する(ステップ11:図示せず)。また、ステップ10においてディスクサブシステム3-1がリモートコピー一時停止状態でない場合、自ディスクサブシステムのリモートコピー状態を一時停止状態解除に変更する(ステップ11:図示せず)。

【0064】尚、ステップ9のようにディスクサブシステム3-2、……3-nがディスクサブシステム3-1に問い合わせる設定であっても、自ディスクサブシステムのリモートコピー状態を表示するなどしたい場合は、自ディスクサブシステム内にリモートコピー状態を保存し、ステップ11及びステップ11'を設けても良い。

【0065】ディスクサブシステム7-1、7-2、……7-nは、ディスクサブシステム3-1、3-2、……3-nから発行されたライトコマンドを受領していることを確認すると、ライトコマンドに対する処理、即ち、自己のサブシステム内のデータバッファ12へのデータ格納処理を行う(ステップ16)。

【0066】ディスクサブシステム7-1、7-2、……、7-nは、ライトコマンドに対する処理、即ち、自己のサブシステム内のデータバッファ12へのデータ格納処理が完了すると、ディスクサブシステム3-1、

3-2、……3-nに対し、ライトコマンドに対する 処理完了報告を行う(ステップ17)。

【0067】なお、一時停止状態が解除されると、ディスクサブシステム3-1、3-2、……3-nは、自サブシステムのリモートコピーの状態が一時停止状態となった時点以後に更新のあったデータの格納位置情報をもとに、当該位置のデータの書き込み指示をディスクサブシステム7-1、7-2、……7-nに対して発行するとともに、上位装置1からディスクサブシステム3-1、3-2、……3-nへデータの書き込み要求が発行された場合は、これに同期して当該データを自己のサブシステム内のデータバッファ12に書き込み、更に、自己のサブシステム内のデータバッファ12にデータが書き込まれたこととは非同期に、遠隔地に存在するディスクサブシステム7-1、7-2、……7-nに対し、データの書き込み指示を行う動作となる。

【0068】本発明により、上位装置1から書き込まれたデータは、ディスクサブシステム3-1、3-2、………、3-nに格納されるだけでなく、ディスクサブシステム7-1、7-2、7-nにも複写され格納される。また、ディスクサブシステム3-1がリモートコピーー時停止状態となった時点のディスクサブシステム3-1、3-2、……3-nのデータの状態が、リモートセンタ10側のディスクサブシステム7-1、7-2、……7-nで生成される。メインセンター9が被災した場合は、ディスクサブシステム7-1、7-2、……7-nのデータを利用して、ジョブを再実行する等の回復作業を行い、業務を再開する。

【0069】なお、リモートセンター10側では、リモートコピーが一時停止状態の間に、ディスクサブシステムのボリューム複写機能等を用いて、ディスクサブシステム7-1、7-2、……・7-nのデータの複製を作成し保存しておく。複製を作成しておくことにより、リモートコピー実行中にメインセンター9が被災し、ディスクサブシステム7-1、7-2、……・7-nにデータが書き込み中であったためにデータの一貫性が損なわれた場合にも、保存しておいた当該データの複製をもと

にジョブを再実行する等の回復作業が行える。

【0070】これらはすべてディスクサブシステムの機能のみで実現され、上位装置の処理能力に対し負担とならない。

[0071]

【発明の効果】上位装置への新規ソフトウェアの導入を 必要とせずサブシステム側の機能変更のみで、ユーザが 期待する範囲での更新データの一貫性を保証でき、導入 が容易なリモートコピーシステムを実現できる。

【0072】また、メインセンターとリモートセンターとの間のデータ送受信の際は、データはまとめられた単位で処理されるため、データ転送効率を向上できるだけでなく、更新順序の整合性を保持するための制御を行うことに起因するサブシステムの制御オーバヘッドも削減できるので、高性能で導入の容易な災害バックアップシステムを提供することができる。

【図面の簡単な説明】

【図1】本発明の一実施の形態におけるリモートコピーシステムの全体構成を示す図である。

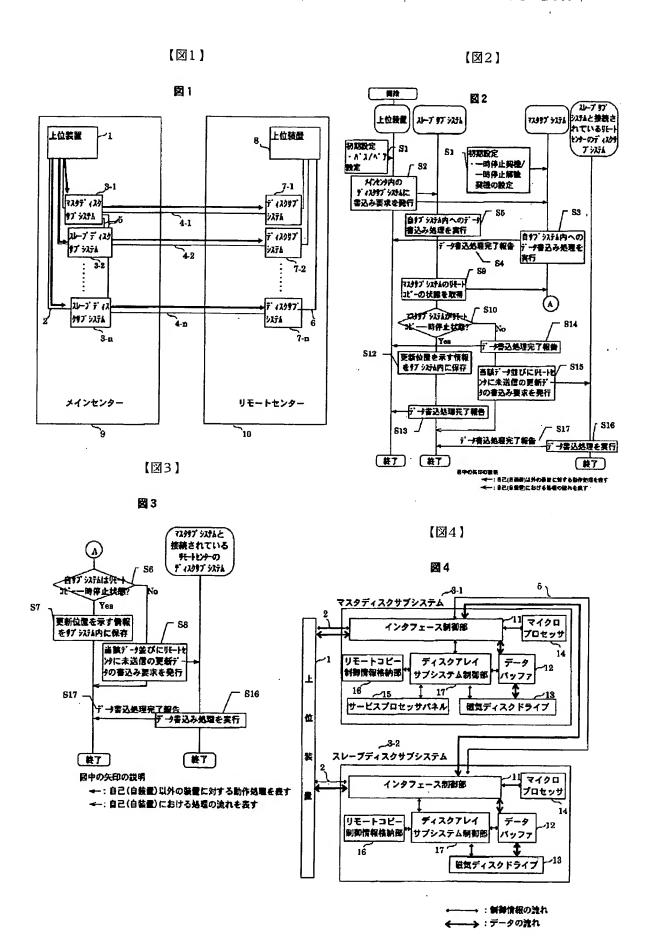
【図2】リモートコピーシステムの処理を示すフローチャートである。

【図3】図2の続きのリモートコピーシステムの処理を示すフローチャートである。

【図4】メインセンターのメインディスクサブシステム 及びスレーブディスクサブシステムの構成を示す図であ る。

【符号の説明】

1…上位装置、2…インタフェースケーブル、3…ディスクサブシステム、4…インタフェースケーブル、5…インタフェースケーブル、5…インタフェースケーブル、6…インタフェースケーブル、7…ディスクサブシステム、8…上位装置、9…メインセンター、10…リモートセンター、11…インタフェース制御部、12…データバッファ、13…磁気ディスクドライブ、14…マイクロプロセッサ、15…サービスプロセッサパネル、16…リモートコピー制御情報格納部、17…ディスクアレイサブシステム制御部。



フロントページの続き

(72)発明者 野沢 正史

神奈川県小田原市国府津2880番地 株式会社日立製作所ストレージシステム事業部内

(72)発明者 中野 俊夫

神奈川県小田原市国府津2880番地 株式会 社日立製作所ストレージシステム事業部内 Fターム(参考) 5B065 BA01 CA12 CE22 EA12 EA33 5B082 DE07 Japanese Published Unexamined Patent Application (A) No. 13209565, published August 3, 2001; Application Filing No. 2000-24687, filed January 28, 2000; Inventor(s): Hideo Tabuchi et al.; Assignee: Hitachi Manufacturing, Inc.; Japanese Title: Subsystems and Total System Therefor

Subsystems and Total System Therefor

CLAIM(S)

1) A total system comprising: a master disk subsystem having a control means for sending/receiving data to/from a higher device and a means of transferring the data and stopping the data transfer to a subsystem located at a remote site at preset intervals; multiple slave disk subsystems, each having a control means for sending/receiving data to/from a higher device, a memory means for storing said data, transmission means connected to said master disk subsystem, an inquiring means for asking whether said master disk subsystem is in status of transferring data or temporarily stopping the data transfer, and a data transfer means of transferring said data, based on the result of said inquiry, to the disk subsystem at a remote site when the master subsystem is in status of transferring the data; multiple remote disk subsystems located at a remote distance from said master disk subsystem and slave disk subsystems and having a control means for receiving the data transferred from said each subsystem and a memory means for storing said data; said total system being characterized in that said

master disk subsystem and slave disk subsystems transfer data to said remote subsystems at the preset intervals; thereby securing consistency of the data in said master and slave subsystems and of the data in said remote disk subsystems during the stopping period of data transfer.

- 2) A method to remote copy data to a slave subsystem, as cited in Claim 1, comprising a step of receiving data from the higher device, a step of storing said data in a memory means, a step of asking the master subsystem whether the master subsystem is in status of transferring data to the remote center, a step of transferring said data to the remote center in the case when said master subsystem is in status of transferring said data, a step of holding the data regarding the position of said stored data in the case when said master subsystem is not in status of transferring said data, and a step of transferring said data after said master subsystem restarts to transfer said data.
- 3) A subsystem comprising a controller for sending/receiving data to/from the higher device, a memory for storing said data, and a data transfer means of transferring the data while temporarily stopping the transfer at a time when said data from said higher device is preset in other subsystem.
- 4) A subsystem, as cited in Claim 3, wherein said subsystem periodically performs a temporary stop and release of data transfer.
- 5) A subsystem, as cited in Claim 4, which holds, at a time of temporary stop of data transfer, the data regarding the stored position of the updated data to be transferred in its own subsystem, until the temporary stop is released.

- 6) A total system comprising: a first subsystem having a controller for sending/receiving data to/from the higher device, a memory device for storing said data, and a transfer section for transferring said data from said higher device to the subsystem located at another site; multiple subsystems, each having a controller for sending/receiving data to/from the higher device, a memory device for storing said data, a transfer section for transferring said data to the subsystem located at another site, and a transmission path connected to said master subsystem.
 - 7) A total system, as cited in Claim 6, wherein said multiple subsystems acquire the transfer status of said first subsystem by using said transmission path.
 - 8) A total system having a controller for sending/receiving data to/from the higher device, a memory device for storing said data, and multiple disk subsystems for transferring said data to the disk subsystems located at another site, characterized in that other disk subsystems send an inquiry to the first disk subsystem out of multiple disk subsystems connected to said higher device as to whether they can transfer said data to said disk subsystems at another site.
 - 9) A total system, as cited in Claim 8, wherein whether said data can be transferred or not is determined by whether said first subsystem is temporarily stopping the data transfer or not.

- 10) A total system, as cited in Claim 9, wherein said first disk subsystem periodically performs said temporary stop and release of data transfer.
- 11) A total system, as cited in Claim 9, wherein the data transfer between said disk subsystem and said disk subsystem at said another site is asynchronously performed.
- 12) A total system having a first disk subsystem group connected to the higher device and a second disk subsystem group for receiving the data transfer from said first disk subsystem group, characterized in that one of the disk subsystems in the first disk subsystem group is a master subsystem for determining whether data can be transferred or not when said first disk subsystem group tries to transfer data to the second disk subsystem group.
- 13) A total system, as cited in Claim 12, wherein whether data can be transferred or not is determined by whether said master subsystem is temporarily stopping the data transfer to said second disk subsystem group.
- 14) A total system, as cited in Claim 12, wherein said first disk subsystem group and said second disk subsystem group are connected by a storage area network (SAN).
- 15) A total system, as cited in Claim 12, wherein data transfer between said first disk subsystem group and said second disk subsystem group is asynchronously performed.
- 16) A total system, as cited in Claim 15, wherein the sequence of data updating is secured by designating a dedicated volume at a time of said asynchronous data transfer.

by a step of receiving data from the higher device, a step of storing said data in the memory, and a step of sending an inquiry to the master subsystem as to whether or not the master subsystem is in status of transferring data to the remote center.

DETAILED DESCRIPTION OF THE INVENTION

(0001)

The present invention pertains to external memory devices for storing data and the total system therefore in a computer system, particularly to a remote data-copying technology, whereby a group of multiple external memory devices on a remote site (subsystems) are connected to another group of multiple external memory devices, and duplicate data are created by the external memory devices on the remote site (subsystems) without using a host computer, which is a higher device. The subsystem mentioned here refers to a memory device having a controller for sending and receiving data to and from the higher device and a built-in disk device for storing data (When the memory device is a disk device, the subsystem is called a disk subsystem.). The total system in this context is defined as a system consisting of multiple subsystems.

(0002)

(Prior Art)

To prepare a back-up copy of data against the cases of natural catastrophe such as earthquake, a primary center and a remoter center need to be apart by a distance of one hundred km – a few hundreds km.

Accordingly, a few types of external memory systems using a remote copying function, wherein duplicate copies are created and stored in the subsystems installed on the primary center and the remote center, respectively, have been developed and put to practical use.

(0003)

A remote copying function is primarily divided into two types: a synchronous type and an asynchronous type.

(0004)

With the synchronous type, when a command to update data is given from the host computer (higher device) to the subsystem and the command is about a remote copying function, completion of the data updating is reported to the higher device of the primary center after the updating task commanded to the subsystem in the remote center is completed. In such a case, the physical distance between the primary center and the remote center

has an impact on the performance of the data transmission path, generating a time delay (transmission time).

(0005)

By contrast, with the asynchronous type, when a command to update data is given from the primary center to the subsystem, completion of the updating task is reported to the higher device as soon as the updating task is completed in the subsystem of the primary center even if object of the command is the remote copying function, and in the subsystem in the remote center, the updating of data (copying of data) is executed asynchronously with the process in the primary center. Since the data updating is completed within the processing time used in the primary center, the transmission time for storing the data in the remote center is not needed [sic].

With the asynchronous type, the content of the subsystem in the remote center is not always consistent with that of the primary center.

Therefore, if the primary center loses the function due to natural catastrophe, the data that have not been copied to the remote center may be lost.

However, the subsystem on the side of the primary center can be accessed at the same level of performance when the remote copying function was not used.

[0007]

The aforementioned prior art system, however, comes with the following problems.

(8000)

"Preserving Data Consistency"

In the process of remote copying, the subsystem of the primary center and the subsystem of the remote center are connected with an independent communication link. More specifically, when the remote copying is performed between multiple subsystems of the primary center and multiple subsystems of the remote center, multiple sets of subsystems, each set being connected with an independent communication link, are used.

In this structure, copying data to the remote center is performed by each communication link, so the time when the data is updated varies depending upon the subsystems. Accordingly, when the primary center loses the function, each subsystem in the remote center has stored the data up to a different point, and therefore the data in the primary center and that in the remote center cannot be consistent once the time cannot be stamped to every data.

(0010)

In the case when the remote center thus creates the back-up copy of data of the primary center having multiple subsystems, there is a problem in securing the sequence of data among multiple subsystems (preserve a sequential order of updating). The "sequence" in this context does not simply mean the "sequential order of data" but means the consistency of updated data in each subsystem.

(0011)

It is inevitable that the copying of the updated data to the remote center is processed at a time point later than the actual updating process at the primary center in asynchronous remote copying. But, the sequence of updating must be consistent with that of the primary center. Even in the intermittent updating, the sequence of updating executed in the primary center must agree with the sequence of updating executed in the remote center in consistent state.

(0012)

A database generally consists of database body, various logging data, and of control data, each being related to one another. When data is updated, not only the database body itself but these logging data and

control data are also updated to preserve the consistency of the systems.

Accordingly, if the sequence of updating data is disrupted, the consistent state of these data related to the sequence of updating data is also disrupted.

In the worst case, the entire database can be possibly destroyed.

(0013)

"Insertion of Higher Device"

When the asynchronous remote copying is performed in general environment where there are multiple subsystems in the primary center and in the remote center and when the higher device commands the subsystems to update data, the data regarding the sequence of updating data, such as data indicating stamped times, are provided to the data body, and based on said data, copying of updated data to the subsystem is generally executed on the auxiliary side. For example, like a remote copying process disclosed in Japanese Unexamined Published Application 06-290125 (U. S. Patent 5446871), the remote copying function is embodied by inserting the higher device.

(0014)

According to the technology disclosed in Japanese Unexamined
Patent Application 06-290125 (U. S. Patent 5446871), the operating system
and the disk subsystem of the higher device in the primary center and the

data mover software and disk subsystem of the higher device in the remote center cooperate to generate and send the data regarding the sequence of updating data and copy the updated data by using this data.

(0015)

(Problems of the Prior Art to Be Addressed)

It is indeed possible to use a remote copying function while securing the sequence of updating data between the primary center and the remote center according to the prior art technology. With this technology, however, the software program of the higher device and the subsystem both have to have a mechanism for using said function and both have to cooperate with each other. Therefore, it becomes necessary to install a new dedicated software program. Then, it becomes necessary for the user to reconsider the system design because of a need of introduction, installation, and inspection of the software program and of an increase of load on the CPU. Therefore, it takes long time and high cost to introduce this function.

In addition, in the case when asynchronous remote copying is executed only by using the function of the subsystem, consistency in sequence of updating data must be preserved only by using the function of the subsystem. However, in the case when the data which need to be

consistent in sequence of updating are distributed to and stored in multiple subsystems, there is a problem that the multiple subsystems do not have a means of preserving the sequence of updated data. There also is another problem that it is necessary to prevent an increase of overhead caused by processing inside the subsystem in order to preserve the sequence of data-updating.

(0017)

The objective of the present invention is to present an asynchronous remote copying function that can secure the consistent state of data only by using the function of the subsystem without installing a new software program on the higher device and that can be easily introduced without reducing the performance of the primary center.

(0018)

(Means to Solve the Problem)

The subsystems of the primary center and of the remote center that are located far apart by a distance are connected to each other. In the case when there are multiple subsystems, one of the subsystems (hereinafter called a master subsystem) is connected to the rest of the subsystems (hereinafter called slave subsystems).

(0019)

The master subsystem of the primary center temporarily stops the remote copying process or releases the temporary stop. These operations can be executed at a proper point in time during the remote copying process by the use's presetting it in the master subsystem. The subsystem of the primary center, upon receiving the updated data from the higher device, begins to store the updated data in its own subsystem.

(0020)

The master subsystem checks whether or not its own subsystem has temporarily stopped a remote copying process. If it has not temporarily stopped the remote copying process, the master subsystem sends the updated data to the remote center. The slave subsystem, upon receiving the updated data from the host, checks the status of the master subsystem by a control bit to be mentioned later, and sends the updated data to the remote center only if it has confirmed that the master subsystem has not temporarily stopped the remote copying process.

(0021)

If the slave subsystem finds that the master subsystem has temporarily stopped the remote copying process, the slave subsystem will likewise temporarily stop the remote copying. When the remote copying process is

data to the remote center, but the primary center alone performs the dataupdating process and its subsystems store the updated data. Once the master
subsystem releases the temporary stop of the remote coping process, the
master subsystem and the slave subsystems restart to send the updated data
to the remote center. In this case, the updated data of the primary center
during said temporary stop is also sent to the remote center.

(0022)

Thus, the data are duplicated by asynchronous remote copying between both volumes in both subsystems of the primary center and of remote center.

(0023)

(Embodiment)

The present invention is explained below with reference to one example in which the present invention is applied to a computer system.

(0024)

Fig. 1 shows said one example wherein data is duplicated by two centers properly selected out of multiple data centers each equipped with a computer system.

(0025)

One or more disk subsystems 3 of the primary center 9 and one or more disk subsystems 7 of the remote center 10 are connected without the higher devices (host computers) 1 and 8, and both centers constitute a remote copying system by performing a task of data duplication. For connecting the disk subsystems without using a higher device, for example, a storage area network (SAN) can be used. Fig. 4 shows one example of the disk subsystem 3 of the primary center 9.

In the primary center 9 of Fig. 1, the higher device 1 having a CPU for conducting data processing is connected to disk subsystem 3-1 (master subsystem) and to slave subsystems, 3-2, ..., 3-n, via interface cable 2, which is a transmission path.

(0027)

The disk subsystems, 3 - 1, 3 - 2, ..., 3 - n, comprises: interface controller 11 for transmitting/receiving data to/from the higher device 1; buffer 12, which the higher device 1 refers to and stores the data for updated data in; remote copying control data storage 16 for storing the data regarding the stored position of the data updated while the remote copying function is temporarily stopping; magnetic disk drive 13 as the recording

medium for recording said data; micro processor 14 for controlling the exchange of these data; and disk array subsystem controller 17 for controlling each of these elements.

(0028)

In addition, the master disk subsystem 3-1 is equipped with service processor panel 15 on which the user sets up how remote copying is performed. The remote copying control data storage 16 stores the control bit indicating the present remote copying status based on the control data preset on the service processor panel 14, as well as the data regarding the stored position of the data updated while the remote copying is temporarily stopping.

(0029)

The master disk subsystem 3-1 is, via the interface cable 4-1, connected to the disk subsystem 7-1 of remote center 10. The slave disk subsystem 3-2 is, likewise, connected, via interface cable 4-2, to the disk subsystem 7-2 of the remote center. The slave disk subsystem 3-n is connected, via the interface cables 4-n, to the disk subsystem 7-n of the remote center.

(0030)

It is also possible to connect the interface cables, 4-1, 4-2, ..., 4-n, to general communication lines by using circuit connection devices. In this context, this option is included in the definition of interface cables 4-1, ..., 4-n.

(0031)

In the case when there are multiple disk subsystems 3, the disk subsystem 3-1 is connected, via the interface cable 5, to the disk subsystems, 3-2, ..., 3-n, other than the disk subsystem 3-1, in which are stored the data to be remote copied in the primary center. Thus, on the side of the primary center 9, the disk subsystem 3, in which the data to be remote copied, is connected to one master disk subsystem 3-1 and to the slave disk subsystems, 3-2, ..., 3-n, via the interface cable 5. (0032)

Once the higher device 1 requests the master disk subsystem 3-1 to input data, the master disk subsystem 3-1, synchronously with this request, inputs said data in the data buffer 12 in its own subsystem, and it also commands, asynchronously with its inputting the data in its own buffer 12, the disk subsystem 7-1 to input the data. Said data that is input in the data

buffer 12 in its own subsystem is synchronously or asynchronously recorded on the magnetic disk drive 13.

(0033)

In the method of asynchronous remote copying by inputting the data in the remote center, the disk subsystem 3 of the primary center 9 sends the updated data to the disk subsystem 7 of the remote center 10 connected to the its own subsystem, in the sequential order in which the volume in its own subsystem has been updated, and the disk subsystem 7 of remote center 10, according to the sequential order of receiving them, sends a set of mode, in which to copy the updated data on the volume in its own subsystem, and of data to be sent at a point in time properly scheduled by disk subsystem 3, without following the sequential order of the volumes updated by the subsystem of the primary center 9. The disk subsystem 7 has a mode for reflecting the updated data on the volume in its own subsystem without following the sequential order of receiving them. (0034)

When the higher disk 1 requests the disk subsystems, 3 - 2, ..., 3 - n, to input the data, the slave disk subsystems, 3 - 2, ..., 3 - n, synchronously with this request, input said data in the data buffer 12 in their own subsystems and also look up the status of the remote copying control data

storage 16 of the master disk subsystem 3-1. Then, according to the remote coping status, they command, asynchronously with said inputting the data in the data buffer 12 in their own subsystems, the disk subsystems, 7-2, ..., 7-n, in the remote site to input the data, or determines whether or not the data regarding the stored position of the updated data should be stored in the remote copy control data storage 16 in their own subsystems. The disk subsystems, 7-1, 7-2, ..., 7-n, store in the data buffer 12 in their own subsystems the data received from disk subsystems, 3-1, 3-2, ..., 3-n, connected by interface cable 4 in the data buffer 12. (0035)

More specifically, when the higher device commands the disk subsystems, 3-1, 3-2, ..., 3-n, to input the data, the same data is stored in one or multiple disk subsystems, 7-1, 7-2, ..., 7-n, in the remote center 10 depending upon the status of the disk subsystem 3-1. The arrow in Fig. 1 shows a flow of data which are to be input by the command of the higher device 1.

(0036)

Since the master disk subsystem 3-1 has the control bit indicating the remote copying status in the remote copying control data storage 16, it can temporarily stop the remote copying process by changing this control bit

data by the command from the system operator at a proper point in time preset by the system operator. When the remote copying is temporarily stopped, the disk subsystems, 3 - 1, 3 - 2, ..., 3 - n, store the updated data in the data buffer in their own disk subsystems while simultaneously storing in the remote copying control data storage 16 the data regarding the stored position of the updated data that is commanded to be input after the temporary stop, and they do not command the disk subsystems, 7 - 1, 7 - 2, 7 - n, to input the updated data. (0037)

In the system of the present invention, since the remote copying is temporarily stopped, the data existing in the primary center 9 when the remote copying is temporarily stopped exist in all the subsystems in the remote center 10. In other words, at a point in time when the temporary stop of remote copying occurred, the data in the primary center 9 and the data in the remote center 10 are consistent. Therefore, stamping of a time for securing the consistency needs not be done to the data, and the remote copying can be implemented without the higher device even for an open system in which the time data is not provided by the higher device.

(0038)

The disk subsystems, 3 - 1, 3 - 2, ..., 3 - n, can release said temporary stop of remote copying based on the command of the system operator at a proper point in time preset at master disk subsystem 3 - 1 by the system operator.

(0039)

Once the temporary stop is released, the disk subsystems, 3 - 1, 3 - 2, ..., 3 - n, command the disk subsystems, 7 - 1, 7 - 2, ..., 7 - n, to input the data updated during the temporary stopping period and if they receive the command from the higher device 1 to input the data, they, synchronously with the command, input said data in the data buffer 12 in their subsystems. Also, they command, asynchronously with said inputting the data in the data buffer 12 in their own subsystems, the disk subsystems, 7-1, 7-2, ..., 7-n, of the remote site to input the data.

By use of the aforementioned structure, same data can be preserved in the volume, which is the object of remote copying, of the disk subsystem 3 of the primary center and in the volume of the disk subsystem 7 of remote center 10 if a time delay in updating can be disregarded. Moreover, while the remote copying is temporarily stopped in the master subsystem 3 –1, the

data status in each disk subsystem 3 of primary center 9 at a time when the master subsystem 3-1 has stopped, i.e. the data status having consistency at said point in time is preserved in each disk subsystem 7 of the remote center 10.

(0041)

The temporary stop and release of remote copying can be set per a volume pair unit of remote copying. It is also possible to arrange multiple volume pairs into one volume group and change the status by a volume group unit. The temporary stop and release of remote copying can be displayed on the subsystems 3 and 7, the consoles of the higher devices 1 and 8, or on the monitor used when these system are controlled. By this, the user can recognize if the remote copying is in progress at present and if the remote copying is performed per a volume group unit.

The time duration between the temporary stop and the release of remote copying can be selected properly by the user as long as it is so short that the temporary stop is released before all the data before the temporary stop occurred are copied to the remote center and new data are copied to the remote center 10, destroying the consistency of the data between the primary center 9 and the remote center 10.

(0043)

The following example takes into account the time for copying and storing the data in subsystem 7 in the remote center 10 at a time of temporary stop of remote copying; in this example, remote copying is performed from the primary center 9 to the remote center 10 for 30 minutes; the remote copying is temporarily stopped for the subsequent 30 minutes; subsequently, the temporary stop is released, and the remote copying is performed again for the subsequent 30 minutes. If the copying time is not 30 minutes in the remote center, the duration of temporary stop may be changed in accordance with the copying time period or the time duration between the temporary stop and the release may be selected regardless of copying time period.

(0044)

It will be also possible to construct a structure wherein the slave disk subsystem needs not consult with the master subsystem on the control bit if the master disk subsystem preliminarily provides, via the interface cable 5, the slave disk subsystems, 3-2, ..., 3-n, with the control bit indicating the remote copying status stored in the remote copying control data storage 16 of the master disk subsystem 3-1. In such a case, the status of the slave

subsystem is stored in the remote copying control data storage 16 of the slave disk subsystem like the case with the remote copying control data storage 16 of the master disk subsystem.

(0045)

The higher device 8 is connected, via the interface cable 6, to the disk subsystems, 7-1, 7-2, ..., 7-1, in the remote center 10, and it is a central processing device to which data is referred, and which stores the updated data in the disk subsystems, 7-1, 7-2, ..., 7-n. The higher device 8 can be a substitute of the higher device 1 when the higher device 1 cannot function due to catastrophe or failure. In addition, the higher device 8 can execute a process different from that performed by the higher device 1 in the primary center 9 independently from the higher device 1 by using the data stored in the disk subsystems, 7-1, 7-2, ..., 7-n. (0046)

However, if the higher device 8 needs not perform a process to the disk subsystems, 7-1, 7-2, ..., 7-n, and does not have a substituting function of higher device 1, the higher device 8 will not be needed. On the contrary, by installing the higher device 8 and connecting the disk subsystem 7-1 to the other disk subsystems, 7-2, ..., 7-n, with interface cable 5, to provide it with the same structure as that of master disk subsystem 3-1 in

the primary center 9, the primary center 9 in Fig. 1 can function as a remote center and the remote center 9 as a primary center.

(0047)

As one form of embodying the present invention, the data duplication method and operation are explained below with reference to Fig. 2. (0048)

The file, volume, disk subsystem 3 in which the data to be duplicated are stored are preliminarily selected by the operator according to a need of duplication, i.e., remote copying. The operator presets, in the remote copying control data storage 16 in the master disk subsystem 3 – 1 by referring to the higher device 1 or service processor 15, the relationship of the file, volume, and disk subsystem 3 to be selected and of the file, volume, and disk subsystem 7 for storing the copied data, as well as a need of constantly preserving the consistency in sequence of data updating.

Generally, only the logging file containing the history of database updating is preset to preserve the consistency in sequence of updating. In this example, however, the presetting to preserve the consistency in sequence of updating data is not done regardless of types of files.

(0049)

With the master subsystem 3 - 1, the time to temporarily stop remote copying and the time to release it are preset. This presetting can be commanded by the higher device 1, so the time for the higher device to issue a command can be preliminarily scheduled by the program of the higher device that supports automation of the operation.

(0050)

In the case of using the disk subsystem 3 to which the dedicated console or service processor 15 can be connected or installed for said selection and presetting, the higher device 1 is not used, but the console or service processor can perform said selection and presetting. In this example, the higher device 1 is not used, but the operator presets so that the periodical temporary stops and releases of remote copying can be executed in the master subsystem 3-1 by using a time value stored in the disk subsystem.

Fig. 2 shows the flow of operation wherein said selection and presetting are done from the dedicated console. The temporary stop and release of remote copying are preset per a volume pair unit to be remote-copied (Step 1: S 1 in the figure.). Generally, all the volume pairs to be

remote-copied are defined as one volume group, and all the volumes in one volume group are preset to share the same status.

(0052)

In this example, all the volumes in the disk subsystem 3 are the objects of remote copying. Accordingly, hereinafter, a remote copying status is described per a disk subsystem unit, not per a volume or volume group. In this example, although the details are not described, in the database and logging file, the presetting is done per every volume group, and the temporary stop and release of remote copying needs not be preset on the volume in which to store the logging file.

(0053)

As to the method of presetting the file and volume which are the objects of remote copying, there is a method to designate a specific address of specific volume or disk system, or a method to select it from a proper range of addresses by the control program in the disk subsystem. The example shows the initial presetting wherein the pass, pair, and temporary stop and release are preset.

(0054)

Once the higher device 1 commands the disk subsystem 3-1 to input data (hereinafter referred to as a write command) (Step 2), the disk

subsystem 3 - 1 stores the data in its own disk subsystem based on the write command (Step 3), reports the completion of the write command to the higher device 1 after having written the data in its own subsystem (Step 4). (0055)

Also, once the higher device issues the write command to the disk subsystems, 3-2, ..., 3-n (Step 2), the disk subsystems, 3-2, ..., 3-n, store the data in their own subsystems based on the write command (Step 5). The write command in this context includes the command to write data and transfer of data to be written. The user presets on the higher device 1 to which subsystem the higher device 1 issues a command (Step 1). (0056)

The disk subsystem 3-1, upon receiving the write command, discriminates the remote copying status by referring to the control bid in the remote copying control data storage 16 that indicates the remote copying status of its own subsystem (Step 6 in Fig. 3). If its own subsystem is temporarily stopping the remote copying, the disk subsystem 3-1 does not send the updated data to the disk subsystem 7-1 of remote center 10 connected to its own subsystem, but stores in its own subsystem the data regarding the stored position of the updated data. (Step 7). If its own subsystem is not in the status of temporarily stopping remote copying, the

disk subsystem 3 – 1 issues the write command to the disk subsystem 7 - 1 at a time determined by the processing capability of its own subsystem. (Step 8)

If the disk subsystem is holding the data regarding the stored position of the data updated during the temporary stopping period of remote copying, it determines the data at said stored position as the object to be sent to the disk subsystem 7 – 1 of the remote center 10, issues the write command to write said data, and deletes the data regarding the stored position of the updated data after having completed the write command process.

(0058)

The disk subsystems, 3-2, ..., 3-n, upon receiving the write command, send, via the interface cable 5, to disk subsystem 3-1 an inquiry about the status of the disk subsystem 3-1 and acquire/look up the control bit indicating the remote copying status of the disk subsystem 3-1 (Step 9) to check out whether the disk subsystem 3-1 is in the status of temporarily stopping the remote copying (Step 10). (0059)

If the disk subsystem 3-1 is in the status of temporarily stopping the remote copying, the disk subsystems, 3-2, ..., 3-n, will store in their own

subsystems the data regarding the stored position of the updated data (Step 12), and report the completion of the write command process to the higher device 1 (Step 13).

If the disk subsystem 3 - 1 is not in the status of temporarily stopping e remote copying, the disk subsystems, $3 - 2, \dots, 3 - n$, report the

the remote copying, the disk subsystems, 3-2, ..., 3-n, report the completion of write command to the higher device 1 (Step 14), and issue the write command to the disk subsystems, 7-2, ..., 7-n, at a time determined by the processing capability of their own subsystems. In addition, if the disk subsystems, 3-1, ..., 3-n, are holding the data regarding the stored position of the updated data, they determine said position data as the object to be sent to the disk subsystems, 7-2, ..., 7-n, of the remote center 9 (Step 15), and delete the position data of the updated data after having completed the write command.

(0061)

(0060)

More specifically, when the disk subsystem 3-1 is in the state of temporarily stopping the remote copying, the other subsystems of the primary center 9 that are connected to the disk subsystem 3-1 enter the state of temporarily stopping the remote copying by the write command of the higher device 1. When the disk subsystem 3-1 is not in the status of

temporarily stopping the remote copying, it remote copies the data to the other disk subsystems of primary center 9 that are connected to the disk subsystem 3 - 1 by the write command from the higher device 1. (0062)

The presetting may also be done as follows: in the case when the remote copying status of the disk subsystem 3-1 is changed, the disk subsystems, 3-1, ..., 3-n, report the change to the disk subsystem 3-1 (Step 9' not shown in the figure) in stead of sending an inquiry to the disk subsystem 3-1 (Step 9), or the disk subsystem 3-1 reports the change to the disk subsystems, 3-2, ..., 3-n, in the case when the remote copying status of the disk subsystem 3-1 is changed, as mentioned earlier. (0063)

With this presetting, the disk subsystems 3-2, ..., 3-n, need, like the subsystem 3-1 does, to store the remote copying status. Therefore, if the disk subsystem 3-1 is in status of temporarily stopping the remote copying in step 10, the disk subsystems, 3-2, ..., 3-n, change the copying status to the temporarily stopping the remote copying (Step 11 not shown in the figure). If the disk subsystem 3-1 is not in the state of temporary stop of remote copying, the disk subsystems, 3-1, ..., 3-n, change the remote

copying status to the release of temporary stop (Step 11' not shown in the figure).

(0064)

In addition, even if the presetting is done so that the disk subsystems, 3-2, ..., 3-n, send the inquiry to the disk subsystem 3-1, they may store the remote copying status in therir own subsystems and perform the step 11 and 11' if the remote copying status in their own disk subsystems needs to be displayed.

(0065)

The disk subsystems, 7-1, ..., 7-n, upon receiving the write command from the disk subsystems, 3-1, ..., 3-n, process the write command, in other words, store the data in the data buffer 12 in their own subsystems (Step 16).

(0066)

The disk subsystems, 7-1, 7-2, ..., 7-n, having completed the process of write command, in other words, having stored the data in the data buffer 12 in their own subsystems, report the completion of the write command process to the disk subsystems, 3-1, 3-2, ..., 3-n (Step 17).

(0067)

Once the temporary stop of remote copying is released, the disk subsystems, 3-1, 3-2, ..., 3-n, command the disk subsystems, 7-1, 7-2, ..., 7-n, to input the data regarding the stored position of the data updated after the remote copying has come to a temporary stop in their own subsystems. If the write command is issued from the higher device 1 to the disk subsystems, 3-1, ..., 3-n, to write the same data, the disk subsystems, 3-1, ..., 3-n, input said data in the data buffer 12 in their own subsystems synchronously with the above write command, and asynchronously with this inputting of said data, they command the disk subsystems, 7-1, ..., 7-n, in the remote site to input said data. (0068)

According to the present invention, the data input in the higher device 1 are not only stored in the disk subsystems, 3 - 1, ..., 3 - n, but also copied to and stored in the disk subsystems, 7 - 1, ..., 7 - n. In addition, the data status in the disk subsystems, 3 - 1, ..., 3 - n, at a time when the disk subsystem 3 - 1 has come to a temporary stop of remote copying is generated in the disk subsystems, 7 - 1, ..., 7 - n, of the remote center 10. In the case when the primary center 9 falls victim to a catastrophe, the data

can be recovered by using the data in the subsystems, 7 - 1, ..., 7 - n, so the operation can be restarted.

(0069)

On the side of remote center 10, the data in the disk subsystems, 7-1, ..., 7-n, are duplicated and stored by using the disk subsystem volume copying function while the remote copying is temporarily stopped. By thus creating the copies, the operation can be restarted by using the stored copies even if the primary center 9 has fallen victim to a catastrophe, therefore, has lost the consistency of data during the operation of remote copying to the disk subsystems, 7-1, ..., 7-n.

This operation of the system is executed only by the functions of the disk subsystems, eliminating a burden on the processing capability of the higher device.

(0071)

(Advantage)

According to the present invention, a remote copying system that can be easily installed while securing consistency of updated data to the extent expected by the user can be implemented only by changing the functions of

the subsystems without introducing a new software application into the higher device.

(0072)

In addition, when data is exchanged back and forth between the primary center and the remote center, the data is processed by a group unit, so the data transmission efficiency is improved, while reducing the control overhead of the subsystems caused by controlling to preserve the consistency in sequence of updating data, by which a high performance back-up system against a catastrophe that can be easily introduced can be presented.

BRIEF DESCRIPTON OF THE DRAWINGS

- Fig. 1 shows the whole structure of the remote copying system as one embodiment example of the present invention.
 - Fig. 2 shows a flowchart of the process in the remote copying system.
- Fig. 3 shows a flowchart of the process in the remote copying system of Fig. 2.
- Fig. 4 shows the structure of the master disk subsystem and slave disk subsystem in the primary center.
- 1. higher device
- 2. interface cable

- 3. disk subsystem
- 4. interface cable
- 5. interface cable
- 6. interface cable
- 7. disk subsystem
- 8. higher device
- 9. primary center
- 10. remote center
- 11. interface controller
- 12. data buffer
- 13. magnetic disk drive
- 14. micro processor
- 15. service processor panel
- 16. remote copying control data storage
- 17. disk array subsystem controller